

基于径向基函数神经网络的滚动轴承故障模式的识别

陆爽, 张子达, 李萌

(吉林大学机械科学与工程学院, 长春 130025)

[摘要] 径向基函数(RBF)神经网络是一种3层前馈性神经网络,它具有较强的函数逼近能力和分类能力。鉴于径向基函数神经网络的优点,在对滚动轴承振动信号特征分析的基础上,提出了采用时序方法对其建立AR模型,利用AR模型参数建立径向基函数神经网络,并用该网络对滚动轴承的故障模式进行了识别。理论和试验证明了该方法的有效性,且具有较高的识别精度。

[关键词] 滚动轴承; 振动信号; AR模型; RBF神经网络; 模式识别

[中图分类号] TH133.33; TP183 **[文献标识码]** A **[文章编号]** 1009-1742(2004)02-0056-05

1 引言

根据滚动轴承在线振动信号监测其运行状态和实时进行故障诊断,是目前既普遍又行之有效的方法^[1,2]。轴承振动信号携带了丰富的运行状态信息,当振动信号从平稳向非平稳过渡时,其突变往往反映了轴承故障引起的撞击、振荡、结构变化、间隙变化和断裂等。图1是对310型轴承检测到的3种工况状态的时域归一化波形。从图1中可见,正常轴承振动信号基本是平稳随机白噪声信号,而故障轴承振动信号则是非平稳随机有色噪声信号。

滚动轴承故障模式识别的任务就是对其振动信号中包含的状态信息进行提取和处理并加以分类,从而推断出滚动轴承运行的状态。由于滚动轴承系统的复杂性和故障形式的多样性,振动信号和状态信息之间并不存在确定的函数关系,信号集与状态集之间是一个复杂的非线性映射。这就决定了滚动轴承故障模式识别的难度和复杂性。

人工神经网络理论为描述这种映射关系提供了有效的工具。它通过对各种标准信号的处理和标准样本的学习,可以将处理和学习过程以权值和阈值模式集中存储和记忆在网络中,这样就可以通过网

络的联想能力实现从信号空间到状态空间的非线性映射,从而达到模式识别的目的。

笔者首先对滚动轴承振动信号在时域中建模,将振动信号转化为时序模型参数,以减小输入欧式空间的维数,然后利用径向基函数网络完成P维欧式空间到Q维欧式空间的非线性映射,从而达到对滚动轴承故障状态进行模式识别的目的。

2 轴承振动信号的自回归AR(P)建模

将轴承振动信号通过时序分析方法建立如下的AR(P)模型

$$x(n) = -a_1x(n-1) - a_2x(n-2) - \dots - a_px(n-P) + w(n), \quad (1)$$

式中 $w(n)$ 是均值为零,方差为 σ_w^2 的白噪声信号。

理论上已证明^[3]:一个自回归模型可以逼近自回归滑动平均模型(ARMA)和滑动平均模型(MA)。这就是说,一个ARMA或MA可以用一个高阶的自回归模型逼近,逼近的精度取决于AR(P)的阶数P。

[收稿日期] 2003-08-21; 修回日期 2003-10-23

[基金项目] 吉林省教育委员会基金资助项目(吉教合字99第10号)

[作者简介] 陆爽(1957-),男,吉林省吉林市人,吉林大学博士研究生,长春大学副教授




图 1 3 种工况轴承振动信号

Fig.1 Vibration signals of bearing under three operating conditions

由于时序模型的系数 $a_i (i = 1, 2, \dots, P)$ 浓缩了原时间序列信号的全部信息，因而可以通过对其系数的研究达到故障模式状态识别的目的。

笔者采用最小二乘原则估计 AR (P) 模型参数。

考虑理想的 AR (P_0) 模型是^[4]

$$x(n) = - \sum_{k=1}^{P_0} a_k x(n-k) + w(n)。 \quad (2)$$

$x(n)$ 的 P 阶线性预测器是

$$\hat{x}(n) = - \sum_{k=1}^P \hat{a}_k x(n-k)。 \quad (3)$$

相应的预测误差序列是

$$e(n) = x(n) + \sum_{k=1}^P \hat{a}_k x(n-k)。 \quad (4)$$

误差平方和是

$$\epsilon_P = \sum |e(n)|^2 = \sum |x(n) + \sum \hat{a}_k x(n-k)|^2。 \quad (5)$$

当 ϵ_P 为最小时可得到估计 \hat{a}_k 。

3 径向基函数 (RBF) 网络

径向基函数网络是以函数逼近理论为基础而构造的一类前向网络，这类网络的学习等价于在多维空间中寻找训练数据的最佳拟合平面。近年来的研究表明^[5~8]，无论在逼近能力、分类能力（模式识别）和学习速度等方面均优于 BP 网络。

RBF 网络的输出为

$$y_i = f_i(\mathbf{x}) = \sum_{k=1}^N W_{ik} \Phi_k(\|\mathbf{x} - \mathbf{c}_k\|_2)。 \quad (6)$$

由于 Gaussian 函数的良好性能，笔者采用

Guassian 函数作为径向基函数：

$$\Phi_k(\mathbf{x}) = \exp\left(-\frac{\|\mathbf{x} - \mathbf{c}_k\|^2}{2\sigma_k^2}\right) \quad (7)$$

由 Gaussian 核函数可看出，它具有两个矢量参数 \mathbf{x} 和 \mathbf{c} ，其中 \mathbf{x} 是函数的自变量矢量，是输入， \mathbf{c} 是常数矢量，是径向基函数的中心。 $\mathbf{x} - \mathbf{c}$ 构成了一个以 \mathbf{c} 为中心的超椭圆， $\Phi(\mathbf{x} - \mathbf{c})$ 就是径向基函数。

径向基函数网络算法如下^[7]：

Guassian 函数网络的学习参数有 3 个，即各 **RBF** 的中心 \mathbf{c}_k 、方差 σ_k 以及输出单元的权值 W_k 。

步骤 1 从输入向量中选一组初始中心值 \mathbf{c}_k ，注意 \mathbf{c}_k 的值要不同。

步骤 2 计算方差值：

$$\sigma = \frac{d_{\max}}{\sqrt{K}} \quad (8)$$

式中 d_{\max} 为最大的 Euclidean 距离； K 为 \mathbf{c}_k 的数量。

步骤 3 初始化输出单位权。

步骤 4 由给定的输入 $x(n)$ 计算输出 $\hat{y}_i(n)$ ：

$$\hat{y}_i(n) = \sum_{k=1}^N W_k \Phi(\mathbf{x}(n), \mathbf{c}_k, \sigma_k) \quad (9)$$

步骤 5 更新 RBF 网络参数：

$$W(n+1) = W(n) + \mu_w e(n) \Psi(n) \quad (10)$$

$$\mathbf{c}_k(n+1) = \mathbf{c}_k(n) + \mu_c \frac{e(n) W_k(n)}{\sigma_k^2(n)}$$

$$\Phi(\mathbf{x}(n), \mathbf{c}_k(n), \sigma_k) (\mathbf{x}(n) - \mathbf{c}_k(n)) \quad (11)$$

$$\sigma_k(n+1) = \sigma_k(n) + \mu_\sigma \frac{e(n) W_k(n)}{\sigma_k^2(n)}$$

$$\Phi(\mathbf{x}(n), \mathbf{c}_k(n), \sigma_k) \|\mathbf{x}(n) - \mathbf{c}_k(n)\|^2 \quad (12)$$

式中：

$$\Psi(n) = \begin{bmatrix} \Phi(\mathbf{x}(n), \mathbf{c}_1, \sigma_1), \Phi(\mathbf{x}(n), \mathbf{c}_2, \sigma_2), L, \\ \Phi(\mathbf{x}(n), \mathbf{c}_N, \sigma_N) \end{bmatrix}^T$$

$e(n) = \hat{y}_i(n) - y_d(n)$ ； $y_d(n)$ 为网络期望输出； μ_w, μ_c, μ_σ 为 3 个参数的学习步长。

步骤 6 如网络收敛，则计算停止，否则转到步骤 4。

4 RBF 网络诊断方法

鉴于时序 AR 模型分析方法在状态特征信息提取上的优势和 RBF 网络的优点，可以将两者有机地结合起来，在时序模型基础上建立径向基神经网络的滚动轴承故障模式的识别模型，如图 2 所示。




图 2 滚动轴承故障模式识别网络模型

Fig.2 Recognizing network model of fault pattern of rolling bearing

由图 2 可见，RBF 神经网络由输入层、输出层和隐层组成，每层包含若干神经元。采集到的滚动轴承振动数据，经过抗混叠滤波的预处理，建立 AR 模型，得到时序模型的特征向量 $\hat{\mathbf{a}}$ 。这些特征向量直接输入 RBF 网络的输入节点，作为网络训练和模式识别的样本参数。用大量反映滚动轴承状态的实测数据对网络进行训练，可得到具有一定精度的稳定网络参数，即建立了能够完成多种故障模式识别的神经网络模型。在该网络的输入节点输入滚动轴承 AR 模型特征向量 $\hat{\mathbf{a}}$ ，经网络前向计算即可完成滚动轴承故障模式的识别。

5 RBF 网络应用于轴承故障模式识别

对 310 型轴承的正常状态、外环故障状态和内环故障状态 3 种工况进行检测，典型时域波形如图 1 所示。试验中共取 36 个轴承，其中正常轴承、外环故障轴承、内环故障轴承各 12 个，每个轴承采样 5 次，每次取 1 024 个数据。用于训练网络的正常轴承 7 个，外环故障轴承 9 个，内环故障轴承 8 个，其余被用于训练后网络的验证。

RBF 网络输入为 AR 模型的特征向量 20 个，隐层神经元个数为 20，输出层含 3 个节点（正常、外环故障、内环故障）。在训练精度为 0.5 % 的情况下，用正常状态数据 25 组，外环故障状态数据 20 组，内环故障状态数据 20 组对 RBF 网络进行训练，得到系统的网络模型。用其余的轴承数据对网络进行验证，表 1 为部分典型 RBF 网络训练和识别结果数据，表 2、表 3、表 4 为训练样本数量与正确识别率的结果。

从表 2、表 3、表 4 可看出，在试验中当训练样本的数量正常状态少于 12，外环故障状态少于 14，内环故障状态少于 12 时，正确识别率低于 70 %；当训练样本数量正常状态大于 32，外环故障状态大于 30，内环故障状态大于 33 时，正确识别率低于 70 %；当训练样本数量正常状态在 22 ~

27, 外环故障状态在 16~26, 内环故障状态在 18~24 时, 正确识别率可达 90 % 以上。可见, RBF 神经网络对于一定的复杂度和训练集规模而言, 确

定有一最佳适中值^[9]。因此, 如何合理地选择训练样本集规模, 也是今后需要进一步研究的理论问题。

表 1 部分 RBF 网络训练和识别结果数据

Table 1 Part data of RBF net training and recognizing results

系数	310 型试验轴承 12 组 AR (20) 模型系数											
	1	2	3	4	5	6	7	8	9	10	11	12
a_1	-0.045 0	0.175 6	0.645 1	0.045 5	0.371 1	-0.427 9	0.642 1	0.460 7	-0.144 2	-0.241 0	-0.228 8	0.964 7
a_2	-0.068 1	-0.276 5	0.088 4	0.153 1	0.390 4	0.946 2	0.669 8	0.612 9	1.079 7	0.889 5	0.973 5	0.320 3
a_3	0.091 9	-0.097 9	-0.078 0	0.006 1	-0.090 5	-0.994 4	-0.298 5	0.040 3	-0.028 2	-0.110 5	0.101 6	0.061 4
a_4	-0.012 2	0.056 4	-0.174 7	0.099 2	0.463 0	1.248 9	-0.215 6	0.308 2	0.606 8	0.270 2	0.338 6	0.093 6
a_5	-0.001 7	0.183 9	-0.127 9	-0.022 8	0.061 4	-1.165 0	-0.278 2	-0.223 2	0.210 0	0.216 3	0.375 2	-0.007 8
a_6	0.053 3	-0.220 5	-0.120 0	0.011 4	0.087 5	1.329 1	0.029 8	-0.105 4	0.196 3	0.024 7	-0.060 6	-0.055 4
a_7	-0.083 8	-0.009 6	-0.077 5	0.061 7	-0.283 3	-1.037 9	0.106 7	-0.286 7	0.283 5	0.228 4	0.396 6	-0.008 3
a_8	0.013 8	0.172 0	0.098 7	0.004 4	0.460 9	1.018 3	0.104 0	-0.042 7	0.240 9	0.047 4	-0.022 9	-0.016 6
a_9	0.138 8	0.181 6	0.114 2	0.144 2	0.109 2	-0.807 5	0.079 2	-0.199 0	0.187 6	0.175 4	0.046 4	-0.038 7
a_{10}	0.024 1	0.114 9	0.065 8	0.060 3	0.304 2	0.507 2	-0.046 2	-0.182 3	0.147 3	0.041 6	0.187 6	-0.025 6
a_{11}	0.014 4	-0.129 5	-0.045 9	-0.009 1	-0.139 7	-0.197 7	-0.081 6	0.064 5	0.145 1	-0.004 6	-0.105 1	-0.164 5
a_{12}	-0.001 3	-0.088 0	-0.106 2	0.021 6	0.263 2	0.060 6	-0.137 4	0.032 6	0.143 7	-0.002 3	0.205 6	-0.002 6
a_{13}	0.012 4	0.103 0	-0.105 6	0.004 7	0.002 3	0.141 6	0.000 3	0.204 3	0.142 6	0.000 5	-0.074 1	0.307 5
a_{14}	0.015 5	0.059 2	0.057 1	-0.041 3	0.099 2	-0.225 6	0.036 8	0.070 8	0.074 5	0.087 7	0.039 7	0.351 7
a_{15}	0.073 7	-0.117 0	0.066 2	-0.067 1	-0.095 9	0.375 1	0.153 3	0.262 7	0.064 5	-0.020 5	0.033 4	0.311 1
a_{16}	-0.029 8	-0.048 8	0.139 1	-0.018 0	0.217 0	-0.278 7	-0.036 3	0.073 6	-0.015 1	0.053 0	-0.074 2	0.189 6
a_{17}	0.061 2	0.145 3	-0.017 6	-0.068 6	0.019 9	0.325 8	-0.090 2	0.120 5	-0.042 0	-0.021 5	0.076 9	0.079 9
a_{18}	-0.056 9	0.020 8	-0.107 9	0.003 7	0.134 5	-0.163 1	-0.073 2	-0.063 7	-0.111 9	-0.069 9	0.003 6	-0.074 9
a_{19}	-0.104 5	0.085 6	-0.002 7	0.052 4	-0.029 4	0.233 6	0.015 9	0.036 3	-0.019 2	0.043 0	0.085 5	-0.119 2
a_{20}	-0.034 6	-0.048 9	-0.064 9	-0.136 8	0.126 5	-0.155 3	0.027 2	-0.043 0	-0.101 1	-0.125 7	0.101 7	-0.006 2
状态	正常轴承	正常轴承	正常轴承	正常轴承	外环故障	外环故障	外环故障	外环故障	内环故障	内环故障	内环故障	内环故障
结果*	训练数据	训练数据	1	1	训练数据	训练数据	2	2	训练数据	训练数据	3	3

* 本栏中, 1 代表正常轴承, 2 代表外环故障轴承, 3 代表内环故障轴承

表 2 正常轴承训练样本数量与正确识别率结果

Table 2 Amount of training samples and accurate recognizing results of normal bearings

训练样本	10	12	14	16	18	20	22	24	26	28	30	32	34
识别结果	0.42	0.57	0.71	0.73	0.72	0.81	0.89	0.92	0.93	0.87	0.82	0.67	0.57

表 3 外环轴承故障训练样本数量与正确识别率结果

Table 3 Amount of training samples and accurate recognizing results of bearings with outer rings fault

训练样本	10	12	14	16	18	20	22	24	26	28	30	32	34
识别结果	0.35	0.67	0.65	0.91	0.94	0.93	0.93	0.91	0.89	0.74	0.65	0.61	0.61

表4 内环轴承故障训练样本数量与正确识别率结果

Table 4 Amount of training samples and accurate recognizing results of bearings with inner rings fault

训练样本	10	12	14	16	18	20	22	24	26	28	30	32	34
识别结果	0.44	0.51	0.72	0.77	0.90	0.92	0.93	0.90	0.85	0.81	0.86	0.71	0.64

6 结语

笔者的研究表明, 径向基函数神经网络用于滚动轴承故障模式识别是非常有效的。只要网络训练集规模选择合理, RBF网络就能准确地完成从滚动轴承振动信号空间到滚动轴承故障状态空间的非线性映射, 较好地满足工程中的需要, 并具有广阔的应用前景。

参考文献

- [1] 何正嘉, 訾艳阳, 孟庆丰, 等. 机械设备非平稳信号的故障诊断原理及应用 [M]. 北京: 高等教育出版社, 2001
- [2] 徐章遂, 房立清, 王希武, 等. 故障信息诊断原理及应用 [M]. 北京: 国防工业出版社, 2001
- [3] Manolakis D G, Ingle V K, Kogon S M. 统计与自适应信号处理 [M]. 北京: 电子工业出版社, 2003
- [4] 屈梁生, 何正嘉. 机械故障诊断学 [M]. 上海: 上海科技出版社, 1986
- [5] Chen S, Cowan C F N, Grant P M. Orthogonal least squares learning algorithm for radial basis function networks [J]. IEEE Trans Neural Networks, 1991, (2): 302~309
- [6] Haykin S. Neural Networks: A Comprehensive Foundation (Second Edition) [M]. Prentice Hall, 1999
- [7] Ham F M, Kostanic I. Principles of Neuro Computing for Science & Engineering [M]. McGraw Hill, 2001
- [8] Hush D R, Horne B G. Progress in supervised neural networks: what's new since Lippmann? [J]. IEEE SP Magazine, 1993, 10 (1): 8~39
- [9] 杨行峻, 郑君里. 人工神经网络与盲信号处理 [M]. 北京: 清华大学出版社, 2003

Fault Pattern Recognition of Rolling Bearing Based on Radial Basis Function Neural Networks

Lu Shuang, Zhang Zida, Li Meng

(College of Machinery and Engineering, Jilin University, Changchun 130025, China)

[Abstract] Radial basis function neural network is a type of three-layer feedforward network. It has many good properties, such as powerful ability for function approximation, classification and learning rapidly. In this paper, in the light of the merit of radial basis function neural network and on the basis of the feature analysis of vibration signal of rolling bearing, AR model is presented by using time series method. Radial basis function neural networks is established based on AR model parameters. In the light of the theory of radial basis function neural networks, fault pattern of rolling bearing is recognized correspondingly. Theory and experiment show that the recognition of fault pattern of rolling bearing based on radial basis function neural networks theory is available and its precision is high.

[Key words] rolling bearing; vibration signal; AR model; RBF neural networks; pattern recognition